

BOJAN BALETIĆ

SVEUČILIŠTE U ZAGREBU
ARHITEKTONSKI FAKULTET
HR – 10000 ZAGREB, KAČIĆEVA 26

UNIVERSITY OF ZAGREB
FACULTY OF ARCHITECTURE
HR - 10000 ZAGREB, KAČIĆEVA 26

DETHODNA PRILOGA

DETHODNA PRILOGA

adata, citation and similar papers at core.ac.uk

brought to you by

ARHITEKTURA I URBANIZAM
2.01.01 - ARHITEKTONSKO PROJEKTIRANJE
ČLANAK PRIMLJEN / PRIHVAĆEN: 10. 11. 2001. / 13. 02. 2002.

ARCHITECTURE AND URBAN PLANNING
2.01.01 - ARCHITECTURAL DESIGNING
ARTICLE RECEIVED / ACCEPTED: 10. 11. 2001. / 13. 02. 2002.

RAČUNALNI POTICAJI ARHITEKTONSKOM STVARALAŠTVU

USING COMPUTERS TO ENCOURAGE ARCHITECTURAL CREATIVITY

BAZE ZNANJA
EKSPERTNI SUSTAVI
GRAMATIKA OBLIKA
INTERAKTIVNA MULTIMEDIJA
NEURALNE MREŽE


KNOWLEDGE BASES
EXPERIMENTAL SYSTEMS
GRAMMAR OF FORM
INTERACTIVE MULTIMEDIA
NEURAL NETWORKS

Rad opisuje računalne sustave, razvijene u posljednjih dvadeset godina, koji iako nisu doživjeli primjenu u arhitektonskoj praksi, posjeduju zanimljive mogućnosti strukturiranja i povezivanja projektantskog znanja, te usmjeravanja i poticanja arhitektove kreativnosti.

The article describes computer systems, developed within the last twenty years, which have never been used in architectural practice but which have interesting possibilities for structuring and combining knowledge about making projects, and guiding and encouraging the architect's creativity.

Uvod

INTRODUCTION



Sl. 1. M. WOLF PLOTTEGG: KOMPJUTORSKA GRAFIKA IZ KATALOGA „DAS BINARE HAUS“, 1989.

FIG. 1 M. WOLF PLOTTEGG: COMPUTER PRINT FROM THE CATALOGUE „DAS BINARE HAUS“, 1989

Razmatramo li ulogu kompjutora kao mogućeg impulsa i podrške u kreativnom činu, moramo nabrojiti više različitih aktivnosti koje često ovise o osobnom pristupu arhitekta. Arhitektonsko je projektiranje složen proces koji uključuje čitav niz aktivnosti: proučavanje problema, skupljanje podataka, izradu i provjeru hipoteza, formalnu artikulaciju prijedloga, razradu prijedloga i detaljniju provjeru fizičkih aspekata prijedloga. Ove aktivnosti u procesu projektiranja rijetko čine linearni slijed, već su, ovisno o sklonostima projektanta, organizirane unutar njegovih strategija na različite načine.

Razvoj kompjutorske tehnologije ponudio je nekoliko „alata“ kao podršku u procesu arhitekta kreativnog djelovanja. Izdvojili smo četiri različita sustava, koje ćemo detaljnije opisati:

- sustav za transformaciju oblika,
- sustav za generiranje arhitektonske kompozicije,
- sustav za navigaciju kroz pojmove,
- sustavi bazirani na znanju.

Većina ovih sustava nije razvijana za potrebe arhitekture, no mogućnost njihove primjene u arhitekturi postoji i vrlo su interesantne. Njihov izbor i implementacija, naravno, ovisi o arhitektovu nazoru i pristupu.

SUSTAVI ZA TRANSFORMACIJU OBLIKA

FORM TRANSFORMATION SYSTEMS

Ovi jednostavni programi omogućavaju transformacije jednog oblika u drugi tijekom određenog broja koraka. Ono što se pojavi u međufazama, neki arhitekti uzimaju kao polaznu inspiraciju. Svojevrsne poetike takvog načina izveli su Manfred Wolf-Plottegg i Peter Eisenman. Ovakav je pristup ograničen, razumljivo, na dekonstruktivistički izraz.

Wolf-Plottegg kreće od odabranih oblika (npr. kuća i krava) i oslanja se na kompjutor da izvede prijelazne kombinacije između njih, od kojih on odabire one koje mu služe kao podloga za razvijanje oblikovnih tema. Te slučajne kombinacije ploha i linija potencijalno predstavljaju, ovisno o njegovu iščitavanju, urbanističke ili arhitektonske kompozicije. Slučajnost je inicijalni mehanizam u kreiranju novih prostornih artefakata (slika 1). Teoretski je okvir svoga rada Wolf-Plottegg izložio u katalogu „Binary House”.¹

I Peter Eisenman sličnu igru oblicima tretira kao oslobađanje i stvaralačku inspiraciju. U prepisci objavljenom u danskom magazinu „Skala” 1987. godine, Eisenman piše:

Pitate me kako odabirem oblike jer ih je mnogo i svi ne odgovaraju. Počeo sam tako da sam s pomoću kompjutora stvarao oblike koje nisam mogao sam napraviti. Osjećam da sam ograničen svojom klasičnom estetikom jer smo odgojeni tako da ovisimo o radu ruku i percepciji oka. Kompjutor me oslobađa i stvara oblike koje ja ne razumijem i za koje nisam ni siguran da mi se sviđaju, ali su mi oni ipak magični jer sadrže nekakvu energiju, nešto tajanstveno što me stalno zanosí... .

U svojim novijim radovima, poput stambenog naselja Rebstock u Frankfurtu (slika 2), Eisenman u sklopu prosedea folding arhitekture koristi kompjutor pri deformiranju rasteza i generiranju slučajnih uzoraka.

SUSTAVI ZA GENERIRANJE ARHITEKTONSKE KOMPOZICIJE

ARCHITECTURAL COMPOSITION GENERATING SYSTEMS

Ovi sustavi nalaze svoju teoretsku podlogu u paraleli između prirodnog jezika i arhitekture. Prirodni se jezik, ističu lingvisti, sastoji od skupine pravila kojima se simboli dovode u odnos kako bi predstavljali šire značenje. Osnovni elementi jezika jesu vokabular, sintaksa, semantika, kontekst i stil. Iako je ovo bitna tema postmodernističkog pokreta u osamdesetim godinama, posebno je bila aktualna kod pojedinih arhitekata koji istražuju kompjutor-

1 WOLF-PLOTTEGG, 1989.


ske primjene u projektiranju. Tako su Coyne i Schmitt u svojim radovima nastojali pokazati da postoje moguće čvrste paralele između arhitekture i lingvističke paradigme. Cilj im je u *budućnosti omogućiti kompjutorima da preuzmu projektantske zadatke na nivou jednog arhitektonskog jezika*.²

Arhitektonski su simboli najmanje jedinice koje sačinjavaju projektantski vokabular. Arhitektonskom vokabularu, odnosno simbolima, potreban je kontekst da bi dobio značenje. Da bi se to postiglo, potrebno je primijeniti tri koncepta: odnose, pravila i gramatiku. Grafički prikaz odnosa u arhitektonskom crtežu jest apstrakcija implicitnih odnosa u zgradi. Grafička reprezentacija odnosa može biti formalizirana u obliku pravila koji tvore gramatiku. Gramatika se koristi kako bi se oblikovao jezik. Stiny je nazvao ovaj postupak gramatikom oblika - ime pod kojim je on danas poznat u kompjutorskoj primjeni.

U praktičnom smislu, gramatika oblika je skup generirajućih pravila za stvaranje oblika. Generiranje počinje inicijalnim oblikom koji se transformira primjenom oblikovnog pravila dok se ne postigne konačni oblik. Jedna gramatika oblika može stvoriti mnogo oblika. No, treba imati na umu, što često napominju stručnjaci, da je moguće koristiti sintaktički pravilnu gramatiku oblika i stvoriti semantički krivi projekt. Ali, katkada i krivo korištenje gramatike oblika može rezultirati vrlo interesantnim i neočekivanim rješenjima.

Na slici 3. prikazane su neke od faza razvoja projekta kuće u stilu F. L. Wrighta na temelju pravila koja su formulirali 1985. godine March i Stiny.³ Gotov projekt nazvan je „Kuća Stiny” prema autoru gramatike oblika (slika 4). Perspektiva izgeneriranoga modela kuće nacrtana je u stilu F. L. Wrighta i obogaćena karakterističnim detaljima u njegovu duhu.

Gramatiku oblika u kontekstu arhitektonskog projektiranja možemo promatrati na dva načina: kao sredstvo edukacije studenata arhitekture koje im omogućava stjecanje intimnijeg uvida u kompozicijske odnose pojedinih stilova, te unutar procesa projektiranja kao način istraživanja brojnih varijacija na određenom temu, među kojima mogu biti i poticajni oblici za daljnje oblikovno istraživanje. U odnosu na postupak u sustavima baziranim na transformaciji oblika, gdje slučajnost ima ključnu ulogu - ovdje kompozicijska pravila odnosno poznata struktura ima primat. Dok je prvi sredstvo dekonstruktivističkog pristupa, drugi podržava pristupe ukorijenjene u tradiciji arhitekture.




Sl. 2. P. Eisenman: Projekt stambenog naselja Rebstock u Frankfurtu, 1991.

Fig. 2 P. Eisenman: Project of the Rebstock Estate in Frankfurt, 1991



² SCHMITT, 1988.

³ RADFORD, STEVENS, 1987.



SL. 3. STINY I MARCH: RAZVOJ PROJEKTA NEPOSTOJEĆE KUĆE U STILU F. L. WRIGHTA KORIŠTENJEM GRAMATIKE OBLIKA, 1985.

FIG. 3 STINY AND MARCH: DEVELOPMENT OF THE INEXISTENT HOUSE PROJECT IN THE F. L. WRIGHT STYLE USING THE GRAMMAR OF FORM, 1985

SUSTAVI ZA NAVIGACIJU KROZ POJMOV

CONCEPT NAVIGATION SYSTEMS

Koncept nazvan *hyper-text*, star nešto više od desetak godina, doživljava danas nevjerovatnu popularnost u okviru razvoja multimedije i Interneta. Multimedijski sustavi i Internet integriraju i nude simultano korištenje teksta, grafike, fotografija, kompjutorske grafike, animacije, videa i zvuka unutar multimedijskih prezentacija ili web stranica - draž kojih je sadržana u interaktivnoj komunikaciji i ne-linearnom kretanju ili naraciji. Upravo nelinearno strukturiranje građe predstavlja doprinos koncepta *hyper-texta*. Korisnik se kreće kroz prostor informacija birajući pojmove koji su analogijama unakrsno vezani s drugim pojmovima. Na taj način on može istraživati i povezivati srodne pojmove unutar različitoga konteksta. Slični, ali specijaliziranim strukama nepoznati aspekti iz različitih disciplina mogu biti povezani, obogaćujući tako naš uvid i svijest o problemu.

U sklopu arhitektonskog projektiranja, multimedijski konglomerat može služiti kao kakva paranoično-kritička tehnologija. U tom smislu aspekte korištenja *hyper-texta* i multimedijskih sustava iznose Heiko Indesen i Matthias Krohn u projektu „Pool-processing”, među kojima izdvajamo dio iz odlomka koji govori o modularizaciji ideja:

Ova je metoda sasvim različita od tradicionalnog korištenja ključnih riječi. U isto vrijeme, hyper-text je reprezentacijska shema i vrsta semantičke mreže koja miješa neformalni tekstualni materijal s više formalnim i mehaniziranim operacijama i procesima.⁴

U drugom odlomku Idensen i Krohn koriste pisanje Theodora H. Nelsona koji ističe da znanje nije „piramida istina” i tvrdi:

U bitnom smislu uopće ne postoje 'subjekti', postoji samo čitavo znanje, budući da se unakrsne veze između bezbrojnih tema ovog svijeta jednostavno ne mogu podijeliti uredno.⁵

Richard D. Coyne vidi ulogu *hyper-text* - koncepta u projektiranju, zajedno s neuralnom mrežom, kao sredstva za poticanje asocijativnog rasuđivanja. U članku „Oruđa za istraživanje asocijativnog rasuđivanja u projektiranju” ističe kako se povezivanje i prisjećanje određenih informacija odnosno primjera asocijacijom, može smatrati jednim oblikom rasuđivanja s pomoću analogija, a predstavlja sredstvo rješavanja projektantskih problema i donošenja odluka (slika 5).⁶

Danas nam je na raspolaganju multimedijska tehnologija. Pred nama je zadatak da stvori-

4 IDENSEN, KROHN, 1989.

5 IDENSEN, KROHN, 1989.

6 COYNE, 1989.

mo nove i „otvorene“ cjeline znanja u kojima će bezbrojne interdisciplinarne veze iluminirati složenost arhitektonskih tema. Tada će multimedija biti stvarna korist za arhitektonsku edukaciju i poticaj projektiranju.

SUSTAVI BAZIRANI NA ZNANIU

KNOWLEDGE-BASED SYSTEMS

Sustavi bazirani na znanju mijenjaju predodžbu o kompjutoru kao izvoru računske snage u onu koja ga predstavlja kao izvor stručnog znanja. To stručno znanje sadrži koncepte, teorije, praktične procedure i različite asocijacije. Znanje se može naći u knjigama i drugim materijalima u eksplicitnom obliku, a kod stručnjaka u implicitnom obliku koji ima heuristički karakter. Cilj razvoja u ovom području jest stvoriti bazu znanja u kompjutoru, koja će biti izvor inteligencije sustavu i na osnovi koje će ugrađeni mehanizmi rasuđivanja donositi zaključke. Osnovno je pitanje: kako možemo formalizirati znanje da bismo ga mogli pohraniti i koristiti u kompjutoru? To je segment istraživanja u području umjetne inteligencije. Danas se ističu dvije vrlo različite tehnologije kao odgovor na to pitanje: ekspertni sustav i neuralna mreža.


EKSPERTNI SUSTAVI

EXPERT SYSTEMS

Ekspertni sustav je program koji pokušava simulirati znanje stručnjaka o određenom problemskom području, iskazano kroz izvedbena pravila (AKO a TADA b). Uloga mu je da služi kao inteligentni savjetnik pri rješavanju problema, nudeći ugrađeno znanje jednog ili nekoliko stručnjaka. To znanje ima heuristički karakter, tj. ono empirijsko znanje koje uključuje iskustvena pravila, naznake, trikove ili druge načine kojima se smanjuje problemsko područje pri traganju za rješenjem.

Ekspertni sustavi postali su od šireg interesa u posljednjih deset godina pojavom komercijalnih ekspertnih školjki koje su omogućile jednostavniju ugradnju i korištenje stručnog znanja. Među uspješnim primjerima ekspertnih sustava jesu oni za medicinsku dijagnostiku, konfiguriranje kompjutorskih sustava, geološka istraživanja, analizu elektronskih sklopova, burzovne transakcije itd.

Među arhitektonskim primjenama nalazimo ekspertne sustave kao uputu za rješavanje različitih praktičnih problema poput konstruktivnih detalja, temeljenja i izolacije, analizu građevinske regulative itd. Ambiciozniji i zahtjevniji sustavi - poput Integriranog okruženja za projektiranje zgrada odnosno IBDE (*Integrated Building Design Environment*) Gerharda Schmitta (slika 6) ili sustav nazvan ICAD (*Intelligent Computer-Aided Design System*)

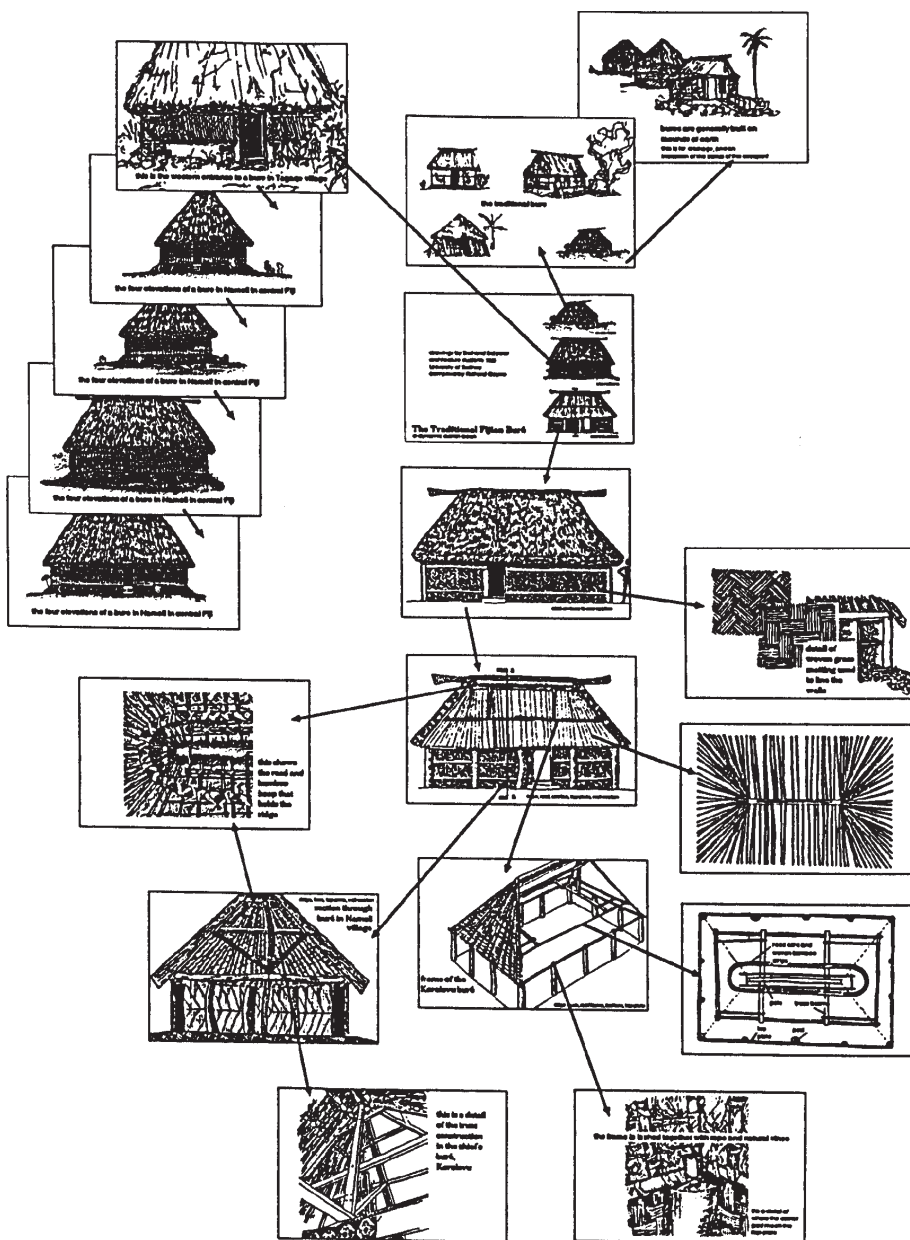


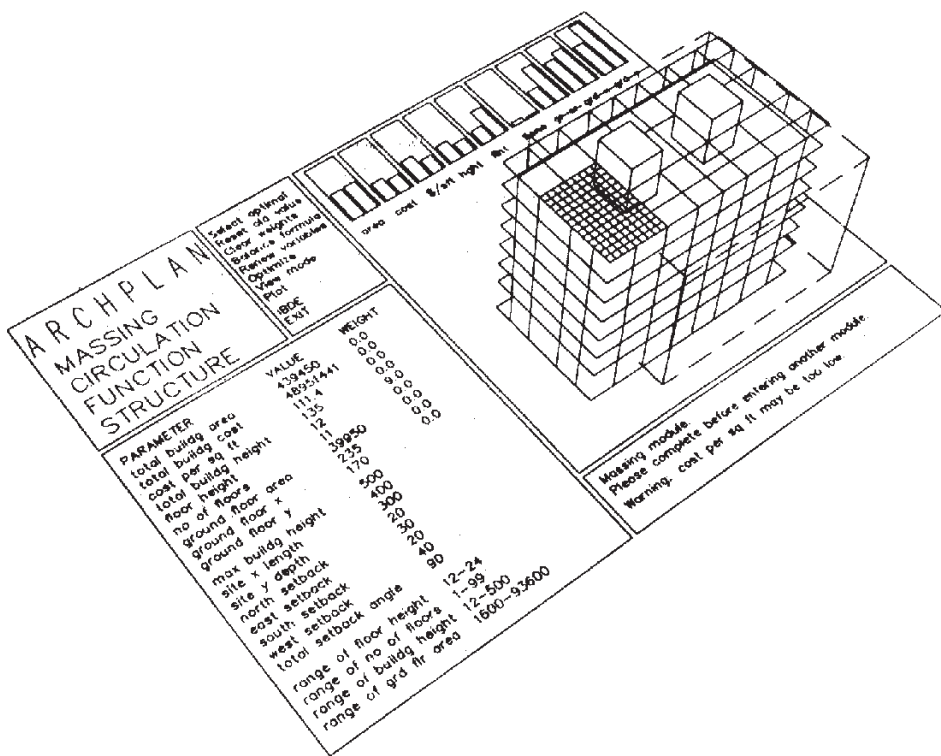
SL. 4. STINY I MARCH: KONAČNI REZULTAT RADA S PRAVILIMA I ELEMENTIMA JEST PROJEKT KUĆE, NACRTAN U STILU F. L. WRIGHTA, KOJOJ JE DANO IME VILLA STINY PREMA TVORCU NJENE GRAMATIKE OBLIKA, 1985.

FIG. 4 STINY AND MARCH: WORK WITH RULES AND ELEMENTS FINALLY RESULTS IN THE PROJECT OF A HOUSE DRAWN IN THE F. L. WRIGHT STYLE, NAMED THE VILLA STINY AFTER THE CREATOR OF ITS GRAMMAR OF FORM, 1985

SL. 5. R. D. COYNE: PRIMJER NELINEARNE ORGANIZACIJE GRAFIČKIH PODATAKA O UROBENIČKOJ KUĆI NA FIJIJU KAO PODLOGA MULTIMEDIJSKOM SUSTAVU ZA POTREBE EDUKACIJE STUDENATA ARHITEKTURE, 1989.


FIG. 5 R. D. COYNE: EXAMPLE OF THE NON-LINEAR ORGANISATION OF GRAPHIC DATA ABOUT AN INDIGENOUS FIJI HOUSE, USED AS THE FOUNDATION FOR A MULTIMEDIA SYSTEM DEVELOPED FOR THE NEEDS OF ARCHITECTURE STUDENTS. 1989





SL. 6. G. SCHMITT: PROJEKTIRANJE NEBODERA UNUTAR EKSPERTNOG SUSTAVA ARCHPLAN

FIG. 6 G. SCHMITT: DESIGNING A HIGH RISE USING THE ARCHPLAN EXPERT SYSTEM



SL. 7. J. POHL I OSTALI: SHEMA EKSPERTNOG SUSTAVA ICAD, 1991.

FIG. 7. J. POHL ET AL.: SCHEME OF THE ICAD EXPERT SYSTEM, 1991.

(slika 7), Jensa Pohla, u kojem je inkorporirano nekoliko ekspertnih sustava u složeni CAD sustav - nisu stekli primjenu izvan svojih istraživačkih laboratorija. Razvijeni ekspertni sustav sastoji se od četiri dijela: baze znanja, sustava za zaključivanje, baze podataka i korisničkog međusklopa.

Ekspertni sustavi mogli bi biti od velike koristi u procesu projektiranja kod rješavanja problema gdje se veze između činjenica i aktivnosti mogu jasno definirati i strukturirati (poglavito funkcionalno-tehnička iskustva). Kao dopuna sadržaju tih sustava, Wojtowicz i Fawcett smatraju da bi oni morali tretirati elemente arhitektonske kompozicije.⁷ Primjena ekspertnih sustava još je uvijek na početku, tako da se njihov daljnji intenzivniji razvoj i šira primjena očekuju tek idućih godina.

No, postoje snažni argumenti protiv ekspertnih sustava, odnosno protiv predstavljanja znanja u obliku pravila, posebno u domeni arhitektonskog projektiranja. Prvo, pri izvlačenju znanja iz primjera u obliku pravila - dio znanja nužno se gubi, a primjeri i njihov kompleksni sadržaj i nadalje se zanemaruju. Ovo je posebno prisutno kad je dobar dio znanja iskazan kroz simboličko značenje korištenjem metafora. Drugo, ekspertni je sustav logički formalizam jer se u njemu provodi deduktivno zaključivanje. Kako pokazuje Mustoe, projektantska je aktivnost ne-monotoničkog karaktera, te se ne može adekvatno prikazati de-

duktivnom logikom.⁸ Unutar strukture pravila nužno bi bilo posjedovati povratne veze između svih točaka sustava, a to je nemoguće u takvom formalizmu. Stoga neki istraživači, poput Mustoea i Coynea, ukazuju na ne-deduktivne tipove sustava koji se temelje na metodomama klasifikacije kao primjerjenije za pohranu i korištenje arhitektonskog iskustva.

NEURALNE MREŽE

NEURAL NETWORKS

Klasificirajući ili konektivistički sustavi, koji su naziv dobili prema strukturi i načinu pohrane znanja, istražuju načine pohranjivanja predstave o postojećem iskustvu preko primjera i mogućnosti zaključivanja o njima na temelju analogija. To znači iznalaženje sličnosti između trenutnog projektantskog zadatka i postojećih primjera koji su pohranjeni u kompjutoru. Neuralne mreže predstavljaju tehnologiju koja se temelji na ovim principima.

Upravo u ovoj razlici ogleđa se podjela, izražena osobito u posljednjih nekoliko godina, između dva dominantna kognitivna modela: klasičnog kognitivizma i konektivizma. Kako navodi Coyne:

Klasični kognitivizam je usmjeren k ideji simbola kao mentalnih reprezentacija. Dobar dio rada na umjetnoj inteligenciji iskorištava mogućnosti ovog pristupa, s naglaskom na pravila i ostala eksplicitna sredstva predstave znanja. Konektivizam, s druge strane, usmjeren je k implicitnim predstavama znanja. Zaoкупljen je modeliranjem, na nižoj razini, ljudskog rasuđivanja u želji da se preslikaju sposobnosti ljudskog rasuđivanja kako bi se transcendirala ograničenja strogo definiranih kategorija i formalne logike.⁹

Sa stajališta projektiranja, zanimljiv aspekt ovih teorija jest da se svaka može koristiti kao određene različite aspekte projektantskog ponašanja i da se svaka može koristiti kao podrška različitim pristupima projektiranju. Klasični kognitivizam podržava usmjerenje na projektantska pravila, hijerarhije tipova i artikulaciju projektantskog procesa. Dole se za konektivizam može reći da naglašava iskustvo i pojavu projektantskih ideja bez pokušaja da se artikulira proces.

Otkrivanje pravih analogija u iskustvu kako bi se iznašli i modificirali prototipovi jest vrlo sofisticiran način rasuđivanja. Unutar sustava prototipovi su organizirani i kodificirani u memoriji. Na temelju ulaznih podataka sustav traži adekvatne uzorke među prototipovima i nudi ih korisniku iako možda ni jedan ne zadovoljava u potpunosti tražene kriterije.

7 WOJTOWICZ, FAWCETT, 1968.

8 MUSTOE, 1990.

9 COYNE, 1991.

je. Ovisno o razini apstrakcije pri definiranju karakteristika kodova moguće je od sustava dobiti i neočekivane primjere. Za razliku od klasičnog principa klasifikacije, kakav nalazimo kod baza podataka gdje su kategorije fiksne, konektivistički pristup nudi fluidan način klasifikacije koji može odgovoriti na neki način i na promjenljivi kontekst korištenja pohranjenih informacija (slika 8).

Sam konektivistički pristup, ističe Coyne, nudi nam unutar arhitektonskog projektiranja da razmotrimo sljedeće aspekte projektiranja:¹⁰

- važnost presedana u procesu projektiranja,
- intuiciju kao oblik neizrecivog znanja koja nadilazi stroga određenja logike,
- artikulaciju projektantskog znanja koje može biti pluralističko i objedinjavati različite kategorije i iskustva te
- vjeru da nove ideje mogu niknuti iz prozaičnih ideja.

Upravo u konektivističkom pristupu Coyne nalazi sredstvo koje projektantu omogućuje i unapređuje „igru s metaforama”. Pristup, po njemu, omogućuje projektantu da „stupi u rudimentarni oblik dijaloga s kompjutorskim sustavom”. Dijalog je oblik koji može unaprijediti prirodu igre s metaforama, evidentne u

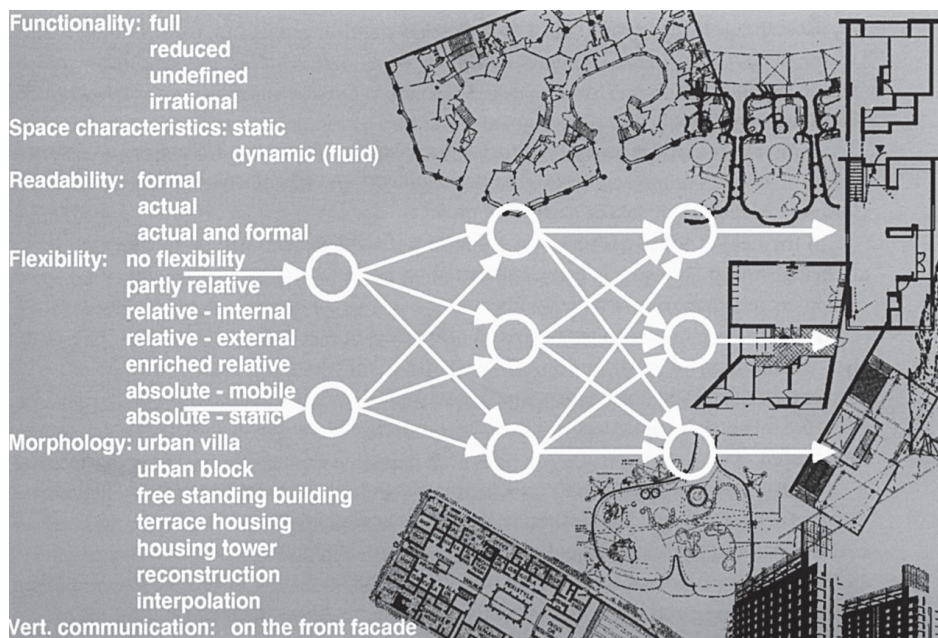
načinu dolaska do rješenja. Ovdje se ne sugerira da konektivizam nudi način simuliranja arhitektova postupka - već se kompjutorski sustav može podesiti da djeluje sa sklonošću prema projektantovu interesu. Dok je kompjutorski sustav nužno ograničen svojim ponašanjem sličnim stroju, dotle projektant može istražiti sposobnosti konektivističkih algoritama koji nude prijedloge te nalaze nove i razumne veze između ideja.

ZAKLJUČAK

CONCLUSION

Navedene tehnologije međusobno su vrlo različite, no zajednički im je pokušaj da se arhitektima u konceptualnoj fazi rada na projektu ponudi impuls koji bi mogao usmjeriti njihov kreativno-istraživački interes. Svrhovitost ovih programa ovisi, naravno, o arhitektovu pristupu. Najveći potencijal za razvoj i primjenu posjeduju sustavi za navigaciju kroz pojmove (u obliku interaktivne multimedije i web stranica) i sustavi bazirani na znanju. Taj potencijal ovisi ponajviše o arhitektima samim jer bi oni trebali u postojeće razrađene tehnologije ugraditi sadržaje koji će biti stručno relevantni i stvaralački provokativni.

¹⁰ COYNE, YUKOZAWA, 1992.

LITERATURA
BIBLIOGRAPHY

SL. 8. B. BALETIĆ: SHema FUNKCIONIRANJA NEURALNE MREŽE ZA PROBLEM STAMBENE JEDINICE, 1995.

FIG. 8 B. BALETIĆ: NEURAL NETWORK FUNCTIONING SCHEME FOR A HOUSING UNIT PROBLEM, 1995

1. COYNE, R. D. (1989.), *Tools for Exploring Associative Reasoning in Design*, The CAAD Futures '89 Conference Computer Aided Design Education, Pre-Publication Edition, The President and Fellows of Harvard College, Edited by McCulough M., Mitchell W. J., Purcell P.
2. COYNE, R. D. (1991.), *Modelling the emergence of design descriptions across schemata*, Planning and Design, Vol. 18.
3. COYNE, R. D., YUKOZAWA, M. (1992.), *Computer assistance in designing from precedent*, Planning and Design, Vol. 19.
4. IDENSEN, H., KROHN, M. (1989.), *An Interactive Media Project Pool-Processing*, Katalog European Media Art Festival 7.-10. 9. 89., Mediakunst Festival, Osnabruck
5. MUSTOE, J. E. H. (1990.), *Artificial intelligence and its application in architectural design*, doktorska disertacija
6. RADFORD, A., STEVENS, G. (1987.), *CAAD Made Easy*, McGraw-Hill, Inc.
7. SCHMITT, G. (1989.), *Classes of Design - Classes of Tools*, The CAAD Futures, 89 Conference Computer Aided Design Education, Pre-Publication Edition, The President and Fellows of Harvard College, Edited by McCulough M., Mitchell W. J., Purcell P.
8. WOJTOWICZ, J., FAWCETT, W. (1968.), *Architecture: Formal Approach*, Academy Editions, London
9. WOLFF-PLOTTEGG, M. (1989.), *Das binare Haus*, Manfred Wolff-Plottegg, Graz

SUMMARY

USING COMPUTERS TO ENCOURAGE ARCHITECTURAL CREATIVITY

Architects use various computer „tools“ in the process of their work. This article gives a detailed description of four such systems: form transformation system, architectural composition generating system, concept navigation system and knowledge-based system. Most of these systems were not developed for the needs of architecture but architects can use them in very interesting ways. Which they will choose and how they will use it depends, of course, on their own views and approach.

Form transformation systems are simple programmes that enable the transformation of one form into another through a certain number of steps. Some architects use the intermediate stages as a starting inspiration.

Architectural composition generating systems are theoretically based on parallels between language and architecture. In practice, the grammar of forms is a set of rules for generating forms. Generating begins with an initial form, which is transformed into the final form through the use of specific formative rules. One grammar may be used to create

many forms. However, experts often caution that syntactically proper grammar can result in a semantically wrong project. However, even if the grammar of forms is not used properly it may sometimes give very interesting and unexpected results.

Concept navigation systems are based on the hyper-text concept and enable non-linear material structuring. The user moves through information space choosing concepts that are cross-linked with other concepts through analogies. In this way he may research and connect kindred concepts within a different context. Similar aspects deriving from various disciplines may be linked, thus enriching insight into and awareness of a problem.

Knowledge-based systems change the approach to the computer as a computing tool into a source of professional knowledge. Two practical forms are present today: expert systems and neural networks. The expert system is a programme that attempts to simulate expert knowledge in a field expressed through rules of realisation. Its role is to provide

intelligent advice in solving problems by offering the built-in knowledge of one of more experts. This knowledge is heuristic in character, i.e. it is empirical and includes rules of experience, indications, tricks and other ways used to decrease the scope of a problem in searching for a solution.

Neural networks were named after the structure of storing knowledge that reflects the working principles of the human brain. They enable experience in projecting to be built into the system through the description of existing examples. After it has completed the learning process, the neural network is ready to use analogy and offer answers to questions. This means it must find similarities between the assignment at hand and rules that are stored in the computer. Depending on the level of abstraction in defining characteristics, the system can give unexpected examples and results.

The above technologies differ greatly but share the goal of guiding the architect's creativity and research in the conceptual stage of work on a project.

BOJAN BALETIĆ

BIOGRAFIJA
BIOGRAPHY

Prof. dr. sc. **BOJAN BALETIĆ**, dipl. ing. arh., izvanredni je profesor na Arhitektonskom fakultetu Sveučilišta u Zagrebu. Osnivač je i voditelj Kabineta za primjenu računala te nositelj kolegija *Primjena računala u arhitekturi*. Bio je voditelj međunarodnih i domaćih znanstvenoistraživačkih projekata iz područja primjene računala u arhitekturi. Autor je većeg broja znanstvenih radova, publiciranih u inozemnim i domaćim zbornicima.

BOJAN BALETIĆ, Dipl. Eng Arch., Ph. D., is associate professor at the Faculty of Architecture, Zagreb University. He is founder and head of the Department for Computer Application and teaches *Using Computers in Architecture*. He has headed international and Croatian research projects in the field of computer use in architecture and has written many research papers, published in foreign and Croatian collections.